

k-NN과 SVM을 이용한 유도전동기 고장 분류

Fault Classification of Induction Motors by k-NN and SVM

*박성무, **이대종, *권석영, *김용삼, *전명근

*충북 청주시, 충북대학교 전기전자컴퓨터공학부

**충북 청주시, 충북대학교 BK21 충북정보기술사업단

E-mail : mgchun@chungbuk.ac.kr

요 약

본 논문에서는 PCA에 의한 특징추출과 k-NN과 SVM에 기반을 계층구조의 분류기에 의한 유도전동기의 고장진단 알고리즘을 제안한다. 제안된 방법은 k-NN에 의해 선형적으로 분류 가능한 고장패턴을 분류한 후, 분류가 되지 않는 부분을 커널 함수에 의해 고차원 공간으로 입력패턴을 매핑한 후 SVM에 의해 고장을 진단하는 계층구조를 갖는다. 실험장치를 구축한 후, 다양한 부하에 대하여 몇몇의 전기적 고장과 기계적 고장 하에서 획득한 데이터를 이용하여 제안된 방법의 타당성을 검증한다.

Key Words : Fault detection, Induction motor, PCA, LDA, wavelet

1. 서 론

산업 현장에 널리 사용하고 있는 유도전동기들의 예기치 않은 고장은 전체 또는 일부 프로세스의 마비로 이어질 수 있으며, 이로부터 치명적인 사고와 경제손실을 초래할 수 있다. 최근, 이러한 고장들에 의한 사고를 미연에 방지할 수 있는 고장진단 기술이 유지보수의 측면과 더불어 중요한 부분으로 부각되고 있다.

일반적으로 유도전동기의 온라인 고장진단은 진동신호 모니터링[1]과 MCSA(motor current signal analysis) [2-4]에 의해서 이루어진다. 과거에는 진동 모니터링에 기반을 둔 연구가 많이 이루어져 있지만, 산업 전반에 사용되고 있는 중소형 유도전동기에 이러한 진단 시스템을 구성하는 것은 센서 및 진단 시스템의 성능 사양을 높이기 위해 많은 비용을 지불해야 하며 또한, 센서의 위치에 따른 성능변화와 전동기 지지 환경에 따른 구조적 진동의 유입 문제를 무시하기가 어렵다. 반면에, MCSA 검출방법을 이용할 경우 절연상태를 제외한 고정자 및 회전자의 정적동적편심 및 베어링의 고장상태를 진단할 수 있다. 또한 온라인 상태에서 고장진단을 수행할 수 있으므로, 최근 이들에 관한 연구가 활발히 진행되고 있다.

MCSA 검출방법에 의해 전류신호를 취득한 후 진단을 위해 사용되는 유도전동기의 고장상

태를 효과적으로 표현할 수 있는 특징추출 기법이 요구된다. 패턴분류 문제에 있어서 주성분분석기법(PCA: principal component analysis)이 사용된다 [5]. 그러나, 주성분분석 기법은 모든 입력차원의 선형성에 기반을 두고 있기 때문에 선형 특성에 대해서는 우수한 결과를 나타내나 비선형특성을 갖는 데이터에 대해서는 최적의 변환행렬을 구할 수 없는 문제점을 지니고 있다. 이러한 이유로 선형분류기인 거리 유사도 방법외에 비선형 분류기인 신경회로망 또는 방사기저함수등의 인공지능기법을 적용하고 있다.

인공지능기법중 대표적으로 사용되는 신경회로망을 이용한 패턴분류기인 경우 일반적으로 역전파 알고리즘이 널리 사용된다. 그러나, 역전파 알고리즘을 쓸 경우 복잡한 입력 패턴의 분포를 추정하기가 어려우므로 학습단계에서 더 많은 양의 학습 데이터가 필요하게 된다. 또한, 지역적 최소값을 피하기 위한 초기화 작업이 거의 경험적으로 이루어지며, 수렴속도가 지연 등의 문제점을 지니고 있다. 또 다른 문제점으로, 신경회로망은 주어진 데이터를 이용하여 경험적 위험을 최소화하는 학습원리인 "경험적 위험 최소화"에 기반을 두고 있다. 그러나 관찰과 경험을 통해 수집할 수 있는 데이터는 유한하며, 데이터의 개수가 충분하지 못할 경우 추정하고자 하는 목적함수의 분포를

효과적으로 반영하지 못할 수 있는 문제점이 있다.

이러한 “경험적 위험 최소화”를 구현하고 있는 대부분의 전통적인 통계적 학습 방법들이 가진 단점을 보완해 줄 수 있는 방법으로서 서포트 벡터 머신인 SVM(support vector machine)기법이 데이터마이닝 분야에 적용되어 우수한 연구결과를 도출하고 있다 [6]. SVM은 Vapnik에 의해 제안된 알고리즘으로 기존의 통계적 학습방법들에서 이용되는 “경험적 위험 최소화”와는 달리 “구조적 위험 최소화”를 이용하여 일반화 오류를 감소시키는 방법에 기반을 두고 있다. 또한 신경회로망과 같은 접근방법들처럼 SVM 역시 비선형 패턴, 곡선함수 추정 등의 다양한 분야에 효과적으로 수행 할 수 있는 능력을 가지고 있다.

따라서 본 논문에서는 주성분분석기법에 의해 입력전류의 특징을 추출한 후, k-NN과 SVM으로 구성된 계층구조의 분류기에 의해서 인버터 구동 유도 전동기의 고장진단 기법을 제안하고자 한다. 제안된 방법의 타당성을 검증하기 위하여 다양한 방법들과 비교가 병행되었으며, 주된 비교 방법으로서 웨이블렛, 선형판별분석기법 등을 고려하였다. 유도 전동기 고장진단 장치를 설계 및 제작한 후, 데이터 취득장치에 의해 실측 데이터를 이용하여 제안된 방법이 기존 방법에 비해 우수한 결과를 보임을 검증 하고자 한다.

2. 제안된 방법

그림 1에서는 본 논문에서 제안된 유도전동기 진단 알고리즘의 구성도를 나타냈다. 그림 1에서 보는 바와 같이, 선형판별분석기법(PCA:Principal Component Analysis)에 의해 입력 전류신호를 저 차원으로 축소한 후, 간단한 k-NN 분류기에 의해 고장을 진단한 후, 2차적으로 서포트 벡터머신에 의해 최종 진단을 하는 계층구조의 분류기에 의해 진단이 이루어진다.

제안된 방법의 기본 개념을 설명하기 위해 실험 데이터에서 취득된 실측데이터를 이용하여 주성분 분석기법에 의해 저차원으로 축소된 결과를 그림 2에 나타냈다. 여기서, 진단 분류로는 정상데이터, 베어링 고장, 회전자 고장, 불평형 등 4가지의 상태를 고려한다. 이에 대한 자세한 설명은 실험부분에 설명하고자 하며, 여기서는 제안된 방법의 기본 개념 및 접근 타당성에 대하여 설명한다.

그림 2에서 보는 바와 같이 정상데이터와 불평형 고장 데이터는 다른 고장데이터와 차별성

이 있는 반면에, 베어링 고장과 회전자 고장은 두 가지 고장의 특성이 유사하여, 특징벡터들 도 서로 겹쳐져 있는 특성이 있음을 확인할 수 있다. 표 1에서는 주성분분석기법에 의해 축소된 차원이 3인 경우와 4인 경우에 대하여 간단한 분류기인 유클리디안 거리기반 k-NN(k=1) 분류기에 의해 진단한 결과를 나타냈다. 표 4에서 보는 바와 같이 축소된 특징벡터의 수가 4인 경우에 정상상태(H)와 불평형 상태(F3)은 진단 성능이 100%로 나왔으나, 베어링 고장(F2)와 회전자고장(F3)은 매우 낮은 인식성능을 보였다. 이 결과로 부터 정상데이터와 불평형 데이터는 간단한 분류기만으로도 진단이 가능하나, 베어링 고장과 회전자 고장은 분류를 위해 성능이 우수한 분류기의 개발이 요구됨을 알 수 있다. 따라서 본 연구에서는 계층구조의 분류기에 의해 유도전동기의 진단성능을 향상시키고자 한다.

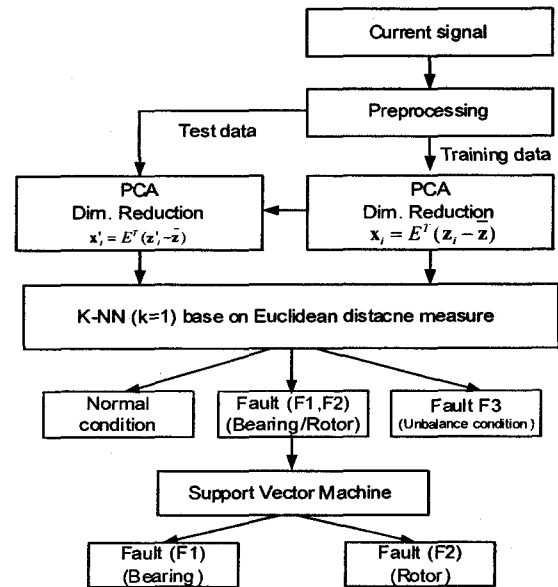


그림 1. 제안된 유도전동기 진단 알고리즘




그림 2. PCA에 의해 얻어진 특징벡터

표 1. PCA와 k-NN에 의한 인식결과

Fault	Feature dimension : 3				Feature dimension : 4			
	H	F1	F2	F3	H	F1	F2	F3
H	66	0	9	0	75	0	0	0
F1	2	54	19	0	0	57	18	0
F2	2	12	61	0	0	12	63	0
F3	0	0	0	75	0	0	0	75

3. 실험 및 결과

3.1 실험장치 구성

유도전동기 고장진단을 위해 설치한 실험장치는 기본적으로 유도전동기 구동부분, 데이터 습득부분과 고장진단부분으로 구성되어 있다. 세부적으로 유도전동기 구동부분은 전동기구동부, 전동기, 안전장치, 다양한 전압표시장치, 전류센서와 진동센서의 구동회로, 그리고 전기적 브레이크 기능을 갖는 부하 시스템을 갖는다. 데이터 습득부분에서는 3-상 전류를 PC로 전송하기 위해 NI사의 PCI-6251 DAQ 보드를 사용하여 10kHz의 샘플링 데이터를 검출한다. 데이터 취득은 PC 상에서 LabVIEW 7.1 프로그램을 이용하여 고장상태별로 데이터를 취득하였다. 표 2는 진단시스템의 기본적 구성요소들의 사양을 보여준다.

표 2. 진단 시스템의 사양

Comp.	Spec.
Induction motor	0.4kW(1/2 HP), 220V, 60Hz 4p, 1700rpm, Efficient: 65%
Current sensor	Rating current: ±10A, Output: ±4V
Data acquisition	500Ks/s, 16bit, 4channel
Load equipment	Brake system of eddy current type
PC	Pentium 4, 2.8GHz

그림 3는 전체 실험장비들의 사진이다. 그림 3에서 볼 수 있듯이 진단 실험시스템은 많은 추가 요소들을 가지고 있다. 먼저 그림 3의 좌측 상단에 있는 인버터는 인버터 구동을 위해 설치하였으며, 구동 전류의 불평형 및 변동을 위해 가변전압기와 가변저항기를 설치하였다. 또한, 실제 산업 현장에서 유도전동기에 부과되는 기계적 부하를 변동시키기 위해 다이내모메타를 설치하였다. 다이내모메타는 맴돌이 전류 방식(Eddy Current Type)의 계동기를 사용하여 부하의 크기를 변동시키는 장치이다. 기타 몇몇의 안전장치와 그림에 나와 있지는 않으나

입력 전원단에 정확한 전원공급을 위해 AVR를 설치하였다.





그림 3. 전체 실험장치의 구성

3.2 고장의 범위 및 데이터 취득

일반적으로 유도전동기의 고장은 수많은 부분에서 다양한 형태로 나타나지만, 제안한 온라인 고장진단 기법의 검증에 사용한 고장의 범위는 정상 데이터, 베어링 고장, 회전자 고장, 전압 불평형 등 네 가지 경우를 고려한다. 고장데이터 중에서, 그림 4(a)에 보인 베어링 고장은 외곽 레일부분의 한 부위에 압착을 가하여 고장을 발생시켰다. 또한 그림 4(b)에 보인 회전자는 회전자의 편심에 드릴로 구멍을 내어 고장을 발생시켰다. 베어링 고장과 회전자 고장 등과 같은 물리적인 고장 외에 전압 불평형에 의한 영향을 고려할 필요가 있다. 이것은 실제 불평형 상에 관계한 전기적 고장들과 같이 전자기 속(flux)을 달라지게 하므로, 고정자 코어에 작용하는 역기전력을 변하게 하며, 입력전류 값을 변화시킨다. 이와 같은 전기적 고장을 구현하기 위해, 그림 3의 상단에 위치한 가변저항기를 전동기 입력 단에 설치하여 한 상에 3%의 불평형 전압을 발생시켰다.

데이터 취득은 LabVIEW 상에서 영점교차점을 이용하여 1초마다 습득하는 1주기의 전류 신호에 대하여 고장진단을 수행한다. 먼저, LabVIEW의 프로그램을 요약하면, DAQ 보드로부터 들어온 입력 데이터들을 주어진 일정 시간마다(1 초) 한 주기(10kHz에서 167개) 샘플을 검출하였다. 실측 데이터는 고장상태별로 부하를 무부하, 0.04 kg·m, 0.08 kg·m, 0.12 kg·m, 0.16 kg·m로 5단계로 분류하여 총 600개의 데이터 (4상태 × 5부하상태 × 30주기)를 취득하였다. 즉 고장상태별로 150개의 데이터를 취득하였으며, 이 중에서 75개는 훈련데이터로 사용하고, 나머지 75개는 검증데이터로 사용하였다.



(a) 베어링 고장 (b)회전자고장
그림 4. 유도전동기의 고장부위

3.3 실험 결과

본 과제에서 제안된 진단알고리즘을 수행하는 첫 번째 단계는 주성분 분석기법을 이용하여 입력신호의 특징을 추출하는 과정이다. 주성분 분석기법을 적용하여 특징을 추출할 경우 몇 개의 차원으로 축소할 지를 결정해야만 한다. 본 논문에서는 실험을 통하여 가장 우수한 진단성능을 보인 25개의 특징을 추출하였다.

실험결과를 표 3에 나타냈다. 표 3에서 보는 바와 같이 주성분분석기법에 의해 특징을 추출한 후, *k*-NN 분류기에 의해 진단한 결과 정상 데이터와 전압불평형 데이터의 경우 100%의 인식결과를 보였으나, 베어링 고장인 경우 94.7%, 회전자 고장의 경우 86.7%로 인식률이 낮게 나타났다. 또한, 선형판별분석기법과 웨이블릿 변환에 의하여 특징을 추출하여 인식률을 분석한 결과 주성분분석기법에 의한 인식결과가 가장 효과적인 것으로 나타났다. 또한, 다층신경회로망과 방사기저함수 등의 인공지능 기법에 의한 분류기법을 적용해 본 결과 *k*-NN 분류기보다 더 낮은 인식결과를 나타냈다. 이와 같이 인식률이 낮게 나타나는 이유는 베어링 고장과 회전자 고장간의 특징벡터들이 서로 겹쳐있는 영역에 의한 것으로 분석된다. 최종적으로 인식률을 향상시키기 위하여, 계층구조의 분류기법을 적용한 결과 97.0%의 인식결과를 보여 *k*-NN 분류방법에 비해 1.7%의 성능향상을 보였다. 따라서, 제안된 방법의 경우 다른 분류기법에 비해 우수한 성능을 보임을 확인할 수 있었다.

4. 결론

본 논문에서는 PCA에 의한 특징추출과 *k*-NN과 SVM에 기반을 계층구조의 분류기에 의한 유도전동기의 고장진단 알고리즘을 제안하였다. 제안된 방법은 우선적으로 선형판별분석기법에 의해 입력 전류신호를 저 차원으로 축소한 후, 간단한 *k*-NN 분류기에 의해 고장을 진단한 후, 2차적으로 서포트 벡터머신에 의해 최종 진단을 하는 계층구조의 분류기에

의해 진단이 이루어진다. 다양한 실측데이터를 이용하여 실험한 결과, 제안된 방법이 기존 방법에 비해 우수한 결과를 보임을 확인할 수 있었다.

표 3. 적용방식별 진단결과 [%]

Classifier	Feature	N	F1	F1	F3	Mean
k-NN	PCA	100	94.7	86.7	100	95.3
	Wavelet	100	73.3	70.7	100	86.0
MLP	PCA	98.7	82.7	2.7	100	71.0
	Wavelet	100	69.3	56.0	100	81.3
RBF	PCA	100	78.7	44.4	100	80.7
	Wavelet	94.7	84.0	61.3	100	85.0
Multi-SVM	PCA	94.7	84.0	81.3	100	91.3
	Wavelet	97.3	85.3	68.0	98.7	87.3
Our method	PCA	100	94.0	92.0	100	97.0
	Wavelet	100	76.0	81.3	100	89.3

참 고 문 헌

- [1] S. Wu, T. Chow, "Induction machine fault detection using SOM-based RBF neural network," *IEEE Trans. Ind. Elect.*, vol. 51, no. 1, pp. 183-194, 2004.
- [2] W. T. Thomson, M. Fenger, "Current signature analysis to detect induction motor faults," *IEEE Ind. Applicat. Magazine*, pp. 26-34, July/August 2001.
- [3] Nejari, M. H. Benbouzid, "Monitoring and diagnosis of induction motors electrical faults using a current Park's vector pattern learning approach," *IEEE Trans. Ind. Applicat.*, vol. 36, no.3, pp. 730-735, 2000.
- [4] Zidani et al., "Induction motor stator faults diagnosis by a current Concordia pattern-based fuzzy decision system," *IEEE Trans. Energy Conversion*, vol. 18, no. 4, pp. 469-475, December 2004.
- [5] Richard O. Duda, Peter E. Hart, David G. Stork, *Pattern Classification*, JOHN WILEY&SONS, Second Edition, 2002.
- [6] Achmad Widodo, Bo-Suk Yang and Tian Han, "Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors", *Expert Systems with Applications*, In Press, Corrected Proof, Available online 4, Jan. 2006.